人間オペレータによるシステムの故障探知について (第1報)^{*1}

モニタの場合

Detection of System Failure by Human Operator (Part 1)

The Case of Monitor

柚原直弘^{*2}・堀内伸一郎^{*2}

Naohiro YUHARA and Shinichiro HORIUCHI

Key Words: Human Engineering, Failure Detection, Human Operator Model, Monitoring Behavior

Abstract

Two types of model, which describes the human monitoring behavior in failure detection task are proposed in this paper. In the first model, detection behavior of human monitor is modeled by two linear optimal estimator (Kalman filter); the failure detection mechanism in the model is based on Wald's Sequential Probability Ratio Test (SPRT). The second model is composed of two fundamental function, that are, linear predictor using autoregressive model and Wald's SPRT. Digital simulations are carried out for checking on the accuracy of proposed models and illustrating the procedure to predict monitor's performance. The simulation results of detection time (the time needed for detecting the failure) and detection accuracy (frequency of miss and/or false alarm) are compared with data obtained from a set of failure detection experiments. From these comparison, it is found that the models can explain adequately the essential characteristics of human operator performing the monitoring task, and also important information for system failure detection by human monitor is rate of visual perception signal. The second model will be applied to a study of failure detection by human controller in a further paper.

1. はじめに

システム運用時の安全性確保には、システム設計時に故障などの不安全事象を明確にし、あらかじめその対応策をたてておくというシステム安全性の事前解析が重要である。安全性の事前解析には安全性の評価規

準としてリスクを用いることが考えられている。リスクはシステムに故障が発生してから、これが探知され適切な処置がとられるまでの時間内に生じる損失の大きさと、故障が顕在化する可能性との兼ね合いの指標である。このような評価規準を構成するには、まず第一に故障を探知するに要する時間を予測する故障探知モデルが必要である。

システムの故障探知はシステムを監視・制御する人間オペレータが行う場合とコンピュータなどの機械を用いて行う場合とに分けられるが、機械による故障探知を行う場合でも探知システム自体が正しく作動しているか否かを監視するために人間の介入が必要となる。また、機械は予測された事態に対してプログラムされた処理だけを行うのに対し、人間は高度の思考能力をもち、過去の経験を総合して予測されなかった新たな事態にも対応することができる。このような理由から機械による故障探知機構を備えたシステムにおいても人間による故障の探知という役割は存在する。

航空の分野においては誘導・制御装置の発達に伴って、人間オペレータ（パイロット）の役割の重点は操縦者としてのものよりも計器の監視者（モニタ）としてのものに移ってきている。このようなモニタリングタスクにおける故障探知（第1図）についてはいくつかの実験が行われており、故障探知モデルも提案されている。GaiとCurry¹⁾は2次系のプラントにおいて故障が出力の平均値変化として表される場合について、一つのカルマンフィルタと逐次確率比検定を組み合わせたモデルを提案し、このモデルによる探知時間の予測値が人間による故障探知実験の結果と定量的によく一致することを示した。また、森住ら²⁾は2次振動系のパラメータが急変する場合においてカルマンフィルタと分散化検定を組み合わせたモデルを提案し、

^{*1} 昭和57年11月12日, 第20回飛行機シンポジウム, 昭和58年11月11日, 第21回飛行機シンポジウムにて発表。昭和60年4月23日原稿受理

^{*2} 日本大学理工学部

第1図 モニタ

実験との比較を行った。その結果、このモデルと実験の探知時間の傾向が定性的には一致することが示された。しかしながら、現在までに知られているような人に人間オペレータの故障探知特性の表現に主眼をおいたモデルでは適用対象や適用条件などに大きな制約があり、上記の目的に用いる探知モデルとしては不十分である。

そこで、本論文では種々の線形プラントおよび故障形態に対応でき、故障探知時間とその標準偏差および誤判定の割合などを予測するためのモニタの故障探知モデルを二つの提案する。第一のモデルはカルマンフィルタを用いたもので、Gai と Curry のモデルをプラントのパラメータが変化する場合などにも適用できるように二つのカルマンフィルタの残差を用いて逐次確率比検定を行うように拡張したものである。第二のモデルは人間の認知する信号を自己回帰 (AR) モデルで表現し、その予測誤差に対して逐次確率比検定を適用するものである。あわせて、これらのモデルを用いた故障探知のシミュレーションと人間による故障探知実験の比較検討を行い、モニタの故障探知特性が定量的に説明できること、人間が表示された信号の微分値に注目して故障を探知していることなどについて述べる。

2. プ ラ ン ト

人間がモニタしているプラントは

$$\dot{x}(t) = Ax(t) + Bu(t) + Dw(t) \quad (1)$$

ディスプレイに表示される出力 $y(t)$ は

$$y(t) = Cx(t) \quad (2)$$

で表される線形定数系で、 x は n ベクトル、 y は m ベクトルである。これを次のように離散値化する。

$$x(k+1) = \Phi x(k) + Fu(k) + \Gamma w(k) \quad (3)$$

$$y(k) = Cx(k) \quad (4)$$

ここで、 k は k 番目のサンプル時点の数値であることを示す。定数マトリクス Φ, F, Γ はサンプリング周期を τ とすると

$$\Phi = e^{A\tau}, F = \int_0^\tau e^{A t} B dt, \Gamma = \int_0^\tau e^{A t} D dt \quad (5)$$

と表される。外乱 w はガウス性白色雑音で、その統計量は

$$E[w(k)] = 0, E[w(k)w^T(l)] = W\delta_{kl} \quad (6)$$

であるとする。

3. カルマンフィルタを用いた故障探知モデル

3.1 推定機構 システムに故障が発生した場合、モニタがその故障を探知できるということは、正常状態と故障状態の両方の信号の特徴を知悉し、その違いを認識できることである。このとき、人間はディスプレイに表示された信号 y を誤差なく認識することはできないので、これを y に対する観測雑音 v としてモデル化する。したがって実際に人間が認知する信号 z は

$$z(k) = y(k) + v(k) \quad (7)$$

となる。ここで v はガウス性白色雑音で、その統計量は

$$E[v(k)] = 0, E[v(k)v^T(l)] = V\delta_{kl} \quad (8)$$

である。

人間はこのような雑音を含んだ信号から真値を推定しているものと考えられるが、プラントが線形であり人間が最良推定を行っているものとすれば、その推定機構はカルマンフィルタで表現される。カルマンフィルタの理論によれば、 k 時点までの観測値 $z(k)$ にもとづく $x(k)$ の推定値 $\hat{x}(k|k)$ は次のような漸化式から計算される。

$$\hat{x}(k|k) = \hat{x}(k|k-1) + K r(k) \quad (9)$$

$$\hat{x}(k|k-1) = \Phi \hat{x}(k-1|k-1) + Fu(k-1) \quad (10)$$

$$r(k) = z(k) - C\hat{x}(k|k-1) \quad (11)$$

ここで、プラントが時不変であるからカルマンゲイン K は

$$P(k|k-1) = \Phi P(k-1|k-1) \Phi^T + \Gamma W \Gamma^T \quad (12)$$

$$P(k|k) = P(k|k-1) - P(k|k-1) C^T V_r^{-1} C P(k|k-1) \quad (13)$$

$$V_r = C P(k|k-1) C^T + V \quad (14)$$

$$K = P(k|k-1) C^T V_r^{-1} \quad (15)$$

からあらかじめ計算できる。

3.2 探知機構 モニタはシステムが正常か異常かを判断するのであるから、システムの状態に対して次のような二つの仮説を用意する。

H_0 : システムは正常

H_1 : システムは異常

ここで、人間ができるだけ早く故障を探知しようとしているとすれば、その探知機構は次のような Wald の逐次確率比検定³⁾を用いて表すことができる。

(1) 観測値 z にもとづいて対数尤度比 $\ln \Lambda(k)$

$$\ln \Lambda(k) = \ln \frac{P(z(1), z(2), \dots, z(k) | H_1)}{P(z(1), z(2), \dots, z(k) | H_0)} \quad (16)$$

を計算する。

(2) $\ln \Lambda(k) \geq \ln A$ であれば仮説 H_1 (故障) を採

択して検定を終わる。

(3) $\ln \Lambda(k) \leq \ln B$ であれば仮説 H_0 (正常) を採択して検定を終わる。

(4) $\ln \Lambda(k) > \ln A$ であれば次の観測値 $z(k+1)$ をとって $\ln \Lambda(k+1)$ を計算する。 H_0 か H_1 のどちらかの仮説が採択されるまでこの手順を繰り返す。

二つのしきい値 A, B は

$$\begin{aligned} A &= (1-\beta)/\alpha \\ B &= \beta/(1-\alpha) \end{aligned} \quad (17)$$

で表される。ここで、 α は仮説 H_0 が正しいにもかかわらず H_1 を採る誤り (false alarm) の確率、 β は仮説 H_0 が正しくないにもかかわらず、これを棄却しない誤り (miss alarm) の確率である。

(16) 式の数尤度比は

$$\ln \Lambda(k) = \ln \Lambda(k-1) + \ln \frac{P(z(k)|z(1), z(2), \dots, z(k-1), H_1)}{P(z(k)|z(1), z(2), \dots, z(k-1), H_0)} \quad (18)$$

と表すことができる。上式の条件付確率密度

$$P(z(k)|z(1), z(2), \dots, z(k-1), H_j) (j=0, 1)$$

は Schweppe⁹⁾ にしたがって、カルマンフィルタの残差 r_j を用いて、

$$\begin{aligned} P(z(k)|z(1), z(2), \dots, z(k-1), H_0) \\ = \frac{1}{\sqrt{(2\pi)^m |V_{r_0}|}} \exp \left\{ -\frac{1}{2} r_0^T(k) V_{r_0}^{-1} r_0(k) \right\} \end{aligned} \quad (19)$$

$$\begin{aligned} P(z(k)|z(1), z(2), \dots, z(k-1), H_1) \\ = \frac{1}{\sqrt{(2\pi)^m |V_{r_1}|}} \exp \left\{ -\frac{1}{2} (r_1(k) - b)^T V_{r_1}^{-1} (r_1(k) - b) \right\} \end{aligned} \quad (20)$$

と表せるので、これらを(18)式に代入して整理すれば

$$\begin{aligned} \ln \Lambda(k) &= \ln \Lambda(k-1) + \frac{1}{2} \left\{ \ln \frac{|V_{r_0}|}{|V_{r_1}|} \right. \\ &\quad + r_0^T(k) V_{r_0}^{-1} r_0(k) - r_1^T(k) V_{r_1}^{-1} r_1(k) \\ &\quad \left. - 2(r_1(k) - b)^T V_{r_1}^{-1} b \right\} \end{aligned} \quad (21)$$

となる。ここで r_0, V_{r_0} は仮説 H_0 に対するカルマンフィルタから得られた残差とその分散、 r_1, V_{r_1}, b は仮説 H_1 に対するカルマンフィルタから得られた残差とその分散、平均値を示す。

故障探知の場合、システムの初期状態は正常であり、システムの変化は正常 (仮説 H_0) から故障 (仮説 H_1) へ変わる場合のみを考えればよいのであるが、上に述べた検定法においては H_0 と H_1 の検定に同等の重みをおいている。したがって、この検定法を故障探知に直接用いると、システムは最初正常であるから $\ln \Lambda(k)$ の平均値は単調減少し、故障が発生して初め

て $\ln \Lambda(k)$ が増加することになるので検定終了までの $\ln \Lambda(k)$ の挙動は第2図のようになる。このことによって故障発生から検定終了までに要する時間に遅れが生じることになる。このような遅れを改善するため Chien と Adams⁹⁾ が提案した零感度スイッチを用い、 $\ln \Lambda(k) < 0$ の場合はつねに $\ln \Lambda(k) = 0$ にリセットするように探知機構を改良する。すなわち

$$\ln \tilde{\Lambda}(k) = \begin{cases} \ln \Lambda(k) & \text{if } \ln \Lambda(k) \geq 0 \\ 0 & \text{if } \ln \Lambda(k) < 0 \end{cases} \quad (22)$$

と定義し、(21)式のかわりに

$$\begin{aligned} \ln \Lambda(k) &= \ln \tilde{\Lambda}(k-1) + \frac{1}{2} \left\{ \ln \frac{|V_{r_0}|}{|V_{r_1}|} \right. \\ &\quad + r_0^T(k) V_{r_0}^{-1} r_0(k) - r_1^T(k) V_{r_1}^{-1} r_1(k) \\ &\quad \left. - 2(r_1(k) - b)^T V_{r_1}^{-1} b \right\} \end{aligned} \quad (23)$$

を用いて対数尤度比関数を計算する。この値がしきい値 $\ln \tilde{A}$ を越えたとき仮説 H_1 を採択して検定を終わる。このしきい値 $\ln \tilde{A}$ は前述の $\ln A$ とは等しくない。それは $\ln \Lambda(k)$ が負の場合を無視しているため、 $\ln \tilde{A} = \ln A$ とすると false alarm の確率が増大するからである。Chien と Adams は故障が出力の平均値変化として表される場合について

$$\tilde{A} - \ln \tilde{A} - 1 = - \left\{ \ln A + \frac{A-1}{1-B} \ln B \right\} \quad (24)$$

の関係を導いている。本論文では故障がプラントのパラメータ変化として表される場合についても(24)式から計算される $\ln \tilde{A}$ を用いる。

以上の探知モデルで対数尤度比関数(23)式に含まれるカルマンフィルタの残差 $r_j (j=0, 1)$ は式(11)式からわかるように実際の出力 z と人間が推定した出力 $C_j \hat{x}_j(k|k-1)$ との差であり、この差の変化によって探知が行われることを示している。 $\hat{x}_j(k|k-1)$ の計算にあたってはプラントの係数マトリックス A_j, B_j, C_j などが既知でなければならないが、これは人間が正常状態、故障状態の信号の特徴を知悉していることに対応している。

ここで、Gai と Curry が取り扱ったように観測値がスカラー量で、故障が出力の平均値変化として表され

第2図 探知時間の遅れ

る特別な場合を考えれば、仮説 H_0 と H_1 に対するカルマンフィルタの残差は平均値のみが異なり、その分散は等しいから (23) 式は

$$\ln \Lambda(k) = \ln \hat{\Lambda}(k-1) + \frac{b}{V_{r_0}} \left\{ r_0(k) - \frac{1}{2} b \right\}$$

と書ける。これが Gai と Curry が用いている対数尤度比関数である。すなわち、Gai らの用いた対数尤度比関数は (23) 式の特別な場合に相当し、故障が出力の平均値変化として表される場合に限り一つのカルマンフィルタですむことがわかる。

3.3 故障探知モデルの性質 以上に述べたモデルの性質を明らかにするため、モデルに含まれる三つのパラメータ

- 1) 仮説 H_1 の大きさ
- 2) 観測雑音 v の大きさ
- 3) 2種類の誤り確率 α, β

の違いが探知時間に及ぼす影響についてシミュレーションによって検討する。

シミュレーションに用いたプラントは伝達関数 $G(s)$ が

$$G(s) = \frac{K\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2}, \quad \zeta = 0.7, \omega_n = 4 \text{ rad/s}, K = 1 \quad (25)$$

で表される2次振動系である。このプラントが定常運転状態のまわりで外乱 w によって変動している場合を考え、(1), (2) 式のように状態変数表示すると

$$\begin{aligned} \begin{bmatrix} \dot{x}_1(t) \\ \dot{x}_2(t) \end{bmatrix} &= \begin{bmatrix} 0 & 1 \\ -\omega_n^2 & -2\zeta\omega_n \end{bmatrix} \begin{bmatrix} x_1(t) \\ x_2(t) \end{bmatrix} + \begin{bmatrix} 0 \\ K\omega_n^2 \end{bmatrix} w(t) \\ y(t) &= [1 \ 0] \begin{bmatrix} x_1(t) \\ x_2(t) \end{bmatrix} \end{aligned}$$

となる。故障としては ζ が減少する方向へ突変する場合 (ζ 故障) を想定する。故障発生は試行開始から15秒後である。

第3図は仮説 H_1 が探知時間に与える影響を示したもので、図の横軸は正常な状態の $\zeta = \zeta_0$ と実際の故障状態の $\zeta = \zeta_1$ との比であり、縦軸は探知時間を示している。この例では観測雑音 v の大きさは文献(6)を参考に出力 y の分散 V_y と v の分散 V の比を $V_y/V = 25 \text{ dB}$ 、誤り確率 α, β は通常の仮説検定で用いられている0.05 (このとき(17), (24)式から計算されるしきい値 $\ln \hat{A}$ は、4.062になる) としている。図中の◎印は仮説 H_1 を $\zeta_1 = 0.49$ (仮説比 $\zeta_1/\zeta_0 = 0.7$) にとったときの平均値、□印は H_1 を $\zeta_1 = 0.56$ ($\zeta_1/\zeta_0 = 0.8$) としたときの平均値である。結果を示す各記号についている縦線はデータの標準偏差の範囲を示している。両者を比較すると、 $\zeta_1/\zeta_0 = 0.8$ のほうが全体的に探知時間が長くなっている。

第3図 仮説比の影響

第4図 観測雑音の影響

第5図 誤り確率の影響

第4図は観測雑音の変化が探知時間に与える影響を示している。◎印は $V_y/V = 25 \text{ dB}$ 、□印は $V_y/V = 15 \text{ dB}$ とした場合の結果である。この図から観測雑音が増加すると探知時間が長くなることがわかる。

第5図は誤り確率の影響を示したものである。誤り確率を $\alpha = \beta = 0.1$ とすると、しきい値 $\ln \hat{A} = 3.075$ となるので $\alpha = \beta = 0.05$ の場合より探知時間が短くなる。

以上の結果から、ここに提案した故障探知モデルによって2次系の減衰比の突変を探知できることが確認

された。また、このモデルによって減衰比の変化だけではなく、固有振動数やゲインの変化なども探知できることは明らかである。

4. AR モデルを用いた故障探知モデル

4.1 予測機構 ここで提案する故障探知モデルは、モニタおよびシステムのループ内で手動制御動作を行うコントローラの両者を同じように取り扱えるものであるが、本論文ではモニタの場合のみを取り扱い、コントローラの場合については第2報で述べる。

このモデルでは3.と同様に、モニタが故障を探知するというのはモニタがプラントの正常および故障の両方の信号の特徴を内部モデルとして記憶しており、故障か否かの判定は正常状態に対する内部モデルの出力と故障状態に対する内部モデルの出力を比較し、実際の出力がどちらの出力に近いかの判断を行うことであると考えられる。すなわち、プラントが正常であると仮定したときに受けとる信号の予測値と故障であると仮定したときに受けとる信号の予測値をARモデルを用いて推定し、実際の信号とこれらの予測値の差の統計的性質から故障を探知するというものである。

まず、時刻 k において人間が認知する m 種類の信号 $X(k)$ を次のような多次元ARモデルで表す。

$$X(k) = \sum_{i=1}^p A(i)X(k-i) + \epsilon(k) \quad (26)$$

ここで X は m 次元ベクトル、 A は $m \times m$ のAR係数行列、 ϵ はガウス性白色雑音ベクトルで、その統計量は

$$E[\epsilon(k)] = 0, E[\epsilon(k) \epsilon^T(l)] = R \delta_{kl} \quad (27)$$

である。ここで X の共分散行列 $S(l)$ を

$$S(l) = E[X(k+l)X^T(k)]$$

と定義し、(26)式の両辺に右から $X^T(k)$ を乗じて期待値をとると

$$S(0) - \sum_{i=1}^p S(i)A^T(i) = R$$

を得る。同様に(26)式の両辺に $X^T(k-1), X^T(k-2), \dots, X^T(k-p)$ を乗じて期待値をとると

$$S(-1) - \sum_{i=1}^p S(i-1)A^T(i) = 0$$

$\vdots$

$$S(-p) - \sum_{i=1}^p S(i-p)A^T(i) = 0$$

が得られる。以上の関係から多次元ARモデルの自己相関関数を与える Yule-Walker 方程式

$$\begin{bmatrix} S(0) & S(1) \cdots S(p-1) & S(p) \\ S(1) & S(0) & S(p-2) & S(p-1) \\ \vdots & \ddots & \vdots & \vdots \\ S(-p+1) & \cdots & S(0) & S(1) \\ S(-p) & \cdots & S(-1) & S(0) \end{bmatrix} \times \begin{bmatrix} I \\ -A^T(1) \\ \vdots \\ -A^T(p-1) \\ -A^T(p) \end{bmatrix} = \begin{bmatrix} R \\ 0 \\ \vdots \\ 0 \\ 0 \end{bmatrix} \quad (28)$$

が得られる。これを解いて $A(i)$ および R の推定値が求まるが、この計算には多次元 Levinson アルゴリズムを用いる。すなわち、 N 点のデータ $X(1), X(2), \dots, X(N)$ が与えられたとき、次のような手順で計算を行う。

$$(1) \quad S(g) = \frac{1}{N} \sum_{i=1}^{N-g} X(i+g)X^T(i), \quad (g=1, 2, \dots)$$

を計算する。

$$(2) \quad \text{次数 } 0 \text{ の自己回帰係数行列 } A_0 \text{ を } 0 \text{ とおく。}$$

(3) $A_p(i), i=1, 2, \dots, p, R_p$ を $p=0, 1, 2, \dots$ に対して逐次、次式を用いて計算する。

$$\hat{R}_p = S(0) - \sum_{i=1}^p \hat{A}_p(i)S^T(i)$$

$$e_p = S(p+1) - \sum_{i=1}^p \hat{A}_p(i)S(p+1-i)$$

$$f_p = S(0) - \sum_{i=1}^p \hat{B}_p(i)S(i)$$

$$D_p = e_p f_p^{-1}, E_p = e_p^T R_p^{-1}$$

$$\hat{A}_{p+1}(i) = \hat{A}_p(i) - D_p \hat{B}_p(p+1-i), (i=1, 2, \dots, p)$$

$$\hat{B}_{p+1}(i) = \hat{B}_p(i) - E_p \hat{A}_p(p+1-i), (i=1, 2, \dots, p)$$

以上の手順を繰り返すことにより $A(i), i=1, 2, \dots, p$ と R の推定値 $\hat{A}(i), \hat{R}_p$ が決定される。このとき、ARモデルの次数 p の決定には赤池の MFPE 法を用いる⁸⁾。すなわち、

$$MFPE(p) = \left(\frac{N+1+mp}{N-1-mp} \right)^l |\hat{R}_p| \quad (29)$$

を最小にする次数を最適次数として選ぶ。このようにしてARモデルが決定できれば、 $k-1$ 時点までの信号を用いて k 時点の信号の予測値 $\hat{X}(k)$ を計算することができる。予測誤差の二乗平均値を最小にする最適予測値 $\hat{X}(k)$ は条件付期待値

$$\hat{X}(k) = E[X(k)|X(1), X(2), \dots, X(k-1)]$$

で与えられるから、ARモデルによる予測値は

$$\begin{aligned} \hat{X}(k) &= E \left[\sum_{i=1}^p \hat{A}(i)X(k-i) + \epsilon(k) | X(1), X(2), \dots, X(k-1) \right] \\ &= \sum_{i=1}^p \hat{A}(i)X(k-i) \end{aligned} \quad (30)$$

から計算される。このとき、予測誤差 $e(k|k-1)$ は

$$\begin{aligned} e(k|k-1) &= X(k) - \hat{X}(k) \\ &= X(k) - \sum_{i=1}^p A(i)X(k-i) \\ &= \varepsilon(k) \end{aligned} \quad (31)$$

となる。したがって、予測誤差の共分散行列の推定値は $\varepsilon(k)$ の共分散の推定値 $\hat{R}$ と等しくなる。

4.2 探知機構 3.2と同様に逐次確率比検定を用いる。すなわち、時刻 k までの信号 $X(1), X(2), \dots, X(k)$ にもとづいて対数尤度比

$$\ln \Lambda(k) = \ln \frac{P(X(1), X(2), \dots, X(k) | H_1)}{P(X(1), X(2), \dots, X(k) | H_0)} \quad (32)$$

を計算し、これをしきい値 $\ln A$, $\ln B$ と比較して検定を行う。(18)式と同様に

$$\begin{aligned} \ln \Lambda(k) &= \ln \Lambda(k-1) \\ &+ \ln \frac{P(X(k) | X(1), X(2), \dots, X(k-1), H_1)}{P(X(k) | X(1), X(2), \dots, X(k-1), H_0)} \end{aligned} \quad (33)$$

であり、条件付確率密度は

$$\begin{aligned} P(X(k) | X(1), X(2), \dots, X(k-1), H_j) \\ = \frac{1}{\sqrt{(2\pi)^m |R_j|}} \exp \left\{ -\frac{1}{2} \varepsilon_j^T(k) R_j^{-1} \varepsilon_j(k) \right\} \\ j=0, 1 \\ R_j = E[\varepsilon_j(k) \varepsilon_j^T(k)] \end{aligned} \quad (34)$$

であるから、 $\ln \Lambda(k)$ は

$$\begin{aligned} \ln \Lambda(k) &= \ln \Lambda(k-1) \\ &+ \frac{1}{2} \left\{ \ln \frac{|R_0|}{|R_1|} + \varepsilon_0^T(k) R_0^{-1} \varepsilon_0(k) \right. \\ &\quad \left. - \varepsilon_1^T(k) R_1^{-1} \varepsilon_1(k) \right\} \end{aligned} \quad (35)$$

となる。ここでも、3.2と同様に探知時間の遅れを改善するため零感度スイッチを設け $\ln \Lambda(k) < 0$ のときは $\ln \Lambda(k) = 0$ にリセットする。探知のしきい値も3.2と同様に(24)式から計算される $\ln \tilde{A}$ を用いる。判定は

(1) $\ln \Lambda(k) \geq \ln \tilde{A}$ であれば仮説 H_1 (故障) を採択して検定終了

(2) $\ln \Lambda(k) < \ln \tilde{A}$ であれば、次の観測値 $X(k+1)$ をとって $\ln \Lambda(k+1)$ を計算する
のように行う。

5. 実験

3, 4で述べた故障探知モデルの妥当性を検証するため、人間オペレータによる故障探知実験を行う。実験は監視しているプラントの正常状態が伝達関数

$$\begin{aligned} G(s) &= \frac{K \omega_n^2}{s^2 + 2\zeta \omega_n s + \omega_n^2}, \\ \zeta &= 0.7, \omega_n = 4 \text{ rad/s}, K = 1 \end{aligned} \quad (36)$$

で表される2次系と

$$G(s) = \frac{K}{Ts+1}, T=0.7, K=1 \quad (37)$$

の1次系について、故障によってパラメータがステップ的に変化する場合をとりあげ、そのステップの大きさ(故障の大きさに相当する)を変化させ、故障の程度を種々想定して行っている。(36), (37)式で表されるプラントをアナログ計算機でシミュレートし、その出力を上下に動く水平輝線としてオシロスコープ上に第6図のように表示する。入力はカットオフ周波数が、2次系のプラントに対しては500 Hz、1次系のプラントに対しては8 Hzとしたガウス性白色雑音であり、ディスプレイのゲインはプラントの正常状態において輝線が $\pm 2 \text{ cm}$ の範囲で動くように調整する。被験者にはあらかじめ予備実験を行わせ、各故障の特徴を十分に把握させる。故障は実験開始後10秒から1分までの間でランダムに発生させ、被験者にはできるだけ早く故障を探知してプッシュスイッチを押すように指示する。故障発生以前にスイッチを押した場合は false alarm, 故障発生後15秒以内に探知されなかった場合は miss alarm とする。一つの故障に対して約20回の練習を行い、21回目以後 false と miss を除いて正しい探知が20回行われた時点までのデータを用いて探知時間の平均値などを計算する。以上の実験結果は6章で故障探知モデルによるシミュレーション結果とともに示す。

次に、故障を探知する際に人間はどのような情報を用いているかについて検討するための実験について述べる。文献6), 7)では補償制御を行っている人間は表示された信号の微分値も制御に用いるとしているが、故障探知においても微分値が重要な役割をもつと考えられる。そこで、第7図のように出力の微分値も同時にオシロスコープ上に表示した場合についても実験を行った。その結果を第8~第10図に示す。これは2次系のプラントにおいて、正常状態 $\zeta_0 = 0.7, \omega_{n0} = 4 \text{ rad/sec}$, $K_0 = 1.0$ からこれらのパラメータが突然変化したときの探知時間を示している。第8図は ζ 故障、第9図は ω_n が変化する場合 (ω_n 故障)、第10図は K が変化する場合 (K 故障) である。各図とも Δ

第6図 ディスプレイフォーマット (e のみを表示した場合)

第7図 ディスプレイフォーマット ($e, \dot{e}$ を表示した場合) 第8図 微分情報の効果 (ζ 故障) 第9図 微分情報の効果 (ω_n 故障)

印はプラント出力のみ、 $\odot$ 印は出力の微分値も同時に表示した場合の結果である。これらの図から、微分情報をあわせて表示した実験のほうが全体的に探知時間が短くなっていることがわかる。これは人間が表示された信号の微分値に注目し、この情報を故障探知に積極的に利用しているためと考えられる。

さらに微分情報の効果について、故障前後の信号の分散変化の面から検討してみる。故障前の出力とその微分値の分散 $\bar{e}(0)$ と $\bar{\dot{e}}(0)$ は一定であり、故障発生後 t 秒経過すると $\bar{e}(t)$, $\bar{\dot{e}}(t)$ に変化する。そこで、人間は第11図のように正常状態の分散と故障した後の分散の差 $\bar{e}(t) - \bar{e}(0)$ あるいは $\bar{\dot{e}}(t) - \bar{\dot{e}}(0)$ を積分

第10図 微分情報の効果 (K 故障)

第11図 積分指標の意味

した量の絶対値がある一定の値に達した時点 T で故障と判定するものと考えると $\left| \int_0^T \{\bar{e}(t) - \bar{e}(0)\} dt \right|$ または $\left| \int_0^T \{\bar{\dot{e}}(t) - \bar{\dot{e}}(0)\} dt \right|$ が一定の値に達したとき故障と判定される。この積分値を正常状態の分散で正規化し、

$$\left| \int_0^T \{\bar{e}(t) - \bar{e}(0)\} dt \right| / \bar{e}(0) \triangleq \bar{E} \geq \bar{A}_1 \quad (38)$$

$$\left| \int_0^T \{\bar{\dot{e}}(t) - \bar{\dot{e}}(0)\} dt \right| / \bar{\dot{e}}(0) \triangleq \bar{E} \geq \bar{A}_2 \quad (39)$$

となった時点で故障が探知されるものと考えられる。第8～第10図の点線は(39)式で表される積分指標 $\bar{E}$ が、故障後の $\dot{e}$ の分散が大きくなる方向では $\bar{E} = 3.0$, 減少する方向では $\bar{E} = 2.0$ となったときの時刻 T を結んだ曲線である。このように ζ, ω_n, K の各故障とも $\bar{E}$ によってよく整理できることがわかる。 $\bar{E}$ ではこのような整理は困難であるから、モニタは $\bar{E}$ に注目している、すなわち出力の微分値に注目して故障を探知していると考えられる。

以上のように、システムの故障探知において微分情報が重要な役割をもち、人間はこの統計的性質に注目して故障を探知しているといえる。

6. モデルと実験との比較

6.1 カルマンフィルタを用いた故障探知モデルとの比較 第12図(a)は2次系の ξ 故障について、モデルと実験の探知時間を比較したものである。モデルの計算では80回のシミュレーションを行い、正しく探知したデータの平均値とその標準偏差を示している。計算においては観測雑音の大きさを $V_y/V=25$ dB, 誤り確率は $\alpha=\beta=0.05$ に選んでいる。また故障仮説における ξ の値 ξ_1 に関しては適切な設定値に関する知識は存在しないので、実験において最も微妙な故障と想定した ξ が0.7倍に変化する場合と同様に $\xi_1/\xi_0=0.7$ としている。図中の Δ 印はモデルの計算で e だけを探知に用いた場合、すなわち、(4)式の y が $y=[e]$ の場合である。故障の程度が大きくなり探知時間が短いときはモデルの結果と実験結果はよく一致するが、 $\xi_1/\xi_0=0.7$ などの微妙な故障ではモデルのほうが探知時間が長くなっている。5章で述べたように

人間は出力の微分値も利用していると考えられるので、モデルの観測値に微分情報も含め、 $y=[e, \dot{e}]^T$ として計算してみると $\odot$ 印で示すように実験結果とよく一致する。これは人間が微分情報を故障探知に用いるという前節の結果がこのモデルに反映されていることを意味している。第12図(b)は故障によって ξ が大きくなる方向に変化する時の結果を示したもので、 ξ が小さくなる場合の仮説比 $\xi_1/\xi_0=0.7$ とほぼ対称に $\xi_1/\xi_0=1.5$ としている。モデルの結果と実験結果の一致は良好である。

第13図(a)は ω_n 故障の場合である。 ξ 故障の場合と同様に仮説比 $\omega_{n1}^2/\omega_{n0}^2=0.7$ としたときの結果が Δ 印で示されている。 ω_n 故障では ξ 故障に比べて全体的に探知時間が短くなっているが、これは実験でも同様な傾向で、両者はよく対応している。ただし、モデルの探知時間のほうが全体的に短くなっているので、 $\omega_{n1}^2/\omega_{n0}^2=0.8$ として計算してみると図中の $\odot$ 印のように実験値にさらに近づきよい一致が見られる。第13図(b)は ω_n が大きくなる方向に変化する

第12図 カルマンフィルタを用いた故障探知モデルと実験との比較 (ξ 故障)

第13図 カルマンフィルタを用いた故障探知モデルと実験との比較 (ω_n 故障)

第14図 カルマンフィルタを用いた故障探知モデルと実験との比較 (K 故障)

場合である。

第14図(a), (b)は故障によって K が変化する場合で、仮説比 K_1/K_0 は ω_n 故障とまったく等しくとっている。この図からわかるように、モデルによる計算結果と実験結果はよく一致し、 K が大きくなる方向と小さくなる方向の探知時間の非対称性なども実験と対応している。

以上のようにカルマンフィルタを用いたモデルと実験はよく一致するが、仮説比は ω_n 故障の場合と ω_n , K 故障の場合とではわずかに異なっている。このことは、第8～第10図の $\bar{E}$ が2.0あるいは3.0になる時間が ω_n , K 故障に比べて長いこと、および ω_n 故障の探知は ω_n , K 故障に比べて難しく、特別な注意をはらわないと探知できないという被験者のコメントとも対応している。

6.2 ARモデルを用いた故障探知モデルとの比較
以上に述べたように人間は表示された信号の微分値を用いていると考えられるので、ARモデルを用いた故障探知モデルによる故障探知のシミュレーションでは

人間の認知する信号を表すベクトル X は

$$X = [\dot{e}]$$

とし、(26)式は1次元ARモデルとする。0.1秒間隔でサンプリングしたデータ1,500点を用い仮説 H_0 , H_1 に対するARモデルを決定しシミュレーションを行う。仮説比と誤り確率はカルマンフィルタを用いたモデルの場合とまったく等しくとっている。

第15図(a), (b)は ζ 故障の結果を比較したものであるが、カルマンフィルタを用いたモデルの場合と同様にモデルの探知時間と実験値はよく一致している。

第16図(a), (b)の ω_n 故障, 第17図(a), (b)の K 故障についてもモデルによる計算は実験値と一致する。また、探知時間の標準偏差や第1表に示す誤判定の割合などもモデルの結果と実験結果はよく一致した傾向を示している。さらに、 ζ 故障に比べて ω_n , K 故障は全体的に探知時間が短いという点、プラントのパラメータが増加する方向と減少する方向では探知時間が非対称である点などの実験結果に見られる特

第15図 ARモデルを用いた故障探知モデルと実験との比較 (ζ 故障)

第16図 ARモデルを用いた故障探知モデルと実験との比較 (ω_n 故障) 第17図 ARモデルを用いた故障探知モデルと実験との比較 (K 故障)

第1表 誤判定の割合(%)

$\xi_f/\xi_o =$		0.2	0.3	0.5	0.7	1.5	2	3	5
FALSE	experiment	0	9	8	39	25	8	9	0
	model	29	26	29	16	20	11	18	20
MISS	experiment	0	0	8	23	13	15	0	0
	model	0	0	1	18	25	2.5	0	0
$\omega_{nf}^2/\omega_{no}^2 =$		0.2	0.3	0.5	0.7	1.5	2	3	5
FALSE	experiment	0	0	9	9	17	17	9	0
	model	11	6	11	13	21	18	16	18
MISS	experiment	0	0	0	0	0	0	0	0
	model	0	0	0	1	0	0	0	0
$K_f/K_o =$		0.2	0.3	0.5	0.7	1.5	2	3	5
FALSE	experiment	0	0	0	38	29	0	9	0
	model	13	19	15	26	15	11	25	35
MISS	experiment	0	0	0	0	0	0	0	0
	model	0	0	0	0	0	0	0	0

微もモデルの計算結果に表れている。なお、これらの計算で $X=[e]$ とおいて微分値を用いないものとして計算するとともに故障では miss alarm が多くなり

第18図 ARモデルを用いた故障探知モデルと実験との比較 (正常状態が異なる場合)

実験結果と一致しない。これは人間が微分情報を用いるという実験および(39)を用いた検討の結果とモデルの性質がよく対応することを意味している。

2次系のプラントにおいて、正常状態を変えた一例を示したものが第18図で、正常状態 $\xi_o=0.7$, $\omega_{no}=1.33$ rad/s, $K_o=1.0$ から故障が発生した場合である。モデルの仮説比、誤り確率などは変化させていない。このようにプラントの正常状態が異なる場合でも、この故障探知モデルの結果は実験値と一致する。

さらに、第19図(a), (b)はプラントが1次系で

第19図 ARモデルを用いた故障探知モデルと実験との比較（1次系）

ある場合の一例として正常状態 $T_0=0.7, K_0=1.0$ の結果を示したものである。モデルの計算において仮説比、誤り確率は2次系の ω_n, K 故障の場合とまったく等しくとっている。この図から、1次系の故障についてもモデルの計算値と実験値はよく一致することがわかる。

7. ま と め

本論ではシステム安全性の事前解析の第1段階として人間オペレータによるシステムの故障探知について検討し、モニタリングタスクを行う人間の故障探知モデルを2種類提案した。さらにモデルを用いたシミュレーションと故障探知実験の比較からモデルの妥当性について検討した。このシミュレーションおよび実験結果から以下のようなことが明らかになった。

- (1) 出力の微分値も表示した実験および(39)式と実験結果との比較から、人間は表示された信号の微分値に注目していることがわかる。
- (2) 二つのカルマンフィルタを用いたモニタの故障探知モデルによって、GaiとCurryのモデルでは扱うことのできなかったプラントのパラメータ変化についても取り扱うことが可能となった。
- (3) この故障探知モデルを用いたシミュレーションは人間が表示された信号の微分値に注目しているという結果をよく説明している。
- (4) ARモデルを用いた故障探知モデルは正常状態が異なる種々の2次系および1次系に対しても仮説比や誤り確率などを変化させることなく実験結果とよく一致する。
- (5) 2種類のモデルとも仮説比の値はまったく等しく、2次系の ξ 故障に対しては
 - ξ が減少する故障: $\xi_1/\xi_0=0.7$
 - ξ が増加する故障: $\xi_1/\xi_0=1.5$ ω_n, K 故障に対しては
 - ω_n, K が減少する故障: $\omega_n^2/\omega_{n0}^2=0.8$
 $K_1/K_0=0.8$
 - ω_n, K が増加する故障: $\omega_n^2/\omega_{n0}^2=1.2$
 $K_1/K_0=1.2$

$K_1/K_0=1.2$

である。ただし、モデルによる探知時間の予測値がわずかに短くなることを許容すれば、 ω_n, K 故障に対しても減少する方向では仮説比0.7、増加する方向では仮説比1.5で実験結果を説明することができる。また、1次系の故障における仮説比は2次系の ω_n, K 故障とまったく等しい。

2種類のモデルを比較すると、探知時間の予測値は両者とも実験値とよく一致するが、実際の予測計算に必要なデータは異なっている。すなわち、カルマンフィルタを用いたモデルではシステムを状態方程式で記述しているので、(1)、(2)式のマトリクス A, B, C や(6)、(8)式で示される外乱と観測雑音の統計量などがすべて既知でなければならないが、ARモデルを用いた故障探知モデルはblack box的モデル化を行っているのでこれらの情報は不必要である。したがって、カルマンフィルタを用いたモデルでは観測雑音が同じとすれば種々のプラントに対して本論文のモデルをそのまま用いることができるが、ARモデルを用いた故障探知モデルでは対象とするプラントのARモデルの次数と係数を決定しておく必要がある。

なお、本論文ではモニタリングタスクの場合のみにについて述べているが、ここで示したARモデルを用いた故障探知モデルは手動制御動作を行う、いわゆるコントローラの場合にも適用可能である。これについては次報で述べる。

参考文献

- 1) Gai, E. G. and Curry, R. E.: A Model of the Human Observer in Failure Detection Tasks, IEEE Trans. on Systems, Man, and Cybernetics, SMC-6 (1976), pp. 85-94.
- 2) 森住 昇, 後藤昇弘, 木村春夫: 人間によるシステム変化検知特性とそのモデル, システムと制御, 27 (1983), pp. 532-537.
- 3) 橋本 毅, 木村春夫: 逐次確率比検定による動的システムのパラメータ急変の探知について, 九大工学集報, 54 (1981), pp. 751-756.
- 4) Schweppe, F. C.: Evaluation of Likelihood Functions for Gaussian Signals, IEEE Trans. on Information

- Theory, IT-11 (1965), pp. 61-70.
- 5) Chien, T. T. and Adams, M. B.: A Sequential Failure Detection Technique and Its Application, IEEE Trans. on Automatic Control, AC-21 (1976), pp. 750-757.
 - 6) Kleinman, D. L., Baron, S. and Levison, W. H.: A Control Theoretic Approach to Manned Vehicle Systems Analysis, IEEE Trans. on Automatic Control, AC-16 (1971), pp. 824-832.
 - 7) 柚原直弘, 清水雅巳: 手動制御系における予測情報の効果について, 第16回飛行機シンポジウム講演集, 1978, pp. 314-317.
 - 8) 赤池弘次, 中川東一郎: ダイナミックスシステムの統計的解析と制御, サイエンス社, 1972.